

課題2の補足

担当教授：植野真臣, TA: 木下 涼

e-mail: kinoshita@ai.is.uec.ac.jp

0.1 全体の流れについて

課題2の目標はspamのテストデータTD.csvの各行(各メール)がスパムか(1をとるか)否か(0をとるか)を(2.3)式で分類し、全行(全メール)に対する正答率を測定することである。

そのためには、パラメータ θ_{x_0} と θ_{ix_0k} をspamの学習データLD.csvから推定しなければならない。

ここでは、パラメータを最尤推定量の式(2.5)により推定する。

式(2.5)を計算するには N, N_{x_0}, N_{ix_0k} をそれぞれ求めなければならない。

N は学習データのサイズ、すなわちLD.csvの行数である。

N_{x_0} は目的変数(一番右側の列)が x_0 という値をとる回数であり、実装では N_0 と N_1 をそれぞれ求める。

N_{ix_0k} は目的変数が x_0 という値をとり、かつ各単語 i が k という値をとるような回数である。実装では、各単語 i に関して $N_{i00}, N_{i01}, N_{i10}, N_{i11}$ を求める。

以上をまとめると、課題2のNB.javaでは、関数"setFrequencyTable"で N_{x_0}, N_{ix_0k} を求め、それを用いて関数"getParameters"でパラメータ θ_{x_0} と θ_{ix_0k} を求め、そのパラメータを用いて関数"classification"でTD.csvの正答率を測定する。

0.2 分類精度のめやす

正しく実装すると、分類精度は0.9以上になる。分類精度が0.869になる人は、うまく学習できておらず、全てのテストデータで目的変数を0と予測していると思われる。